

기동표적의 위치추적을 위한 적응 퍼지 IMM 알고리즘

Adaptive Fuzzy IMM Algorithm for Position Tracking of Maneuvering Target

김현식

Hyun-Sik Kim

동명대학교 로봇시스템공학과

요약

실제 시스템 적용에 있어서, IMM에 기초한 위치 추적 알고리즘은 불확실한 표적 기동에 대해서 강인한 성능, 적은 연산량, 간편한 설계 절차를 필요로 한다. 이 문제들을 해결하기 위해서 잘 정의된 기저 부모델 및 잘 조정된 모델 천이 확률에 기초한 적응 퍼지 IMM 알고리즘을 제안하였다. 시뮬레이션 결과는 제안된 알고리즘이 IMM에 기초한 알고리즘의 실제 적용에서 존재하는 문제점을 효과적으로 해결할 수 있음을 보여준다.

키워드 : 기동 표적, 위치 추적, 적응 퍼지 IMM, 기저 부모델, 모델 천이 확률

Abstract

In real system application, the IMM-based position tracking algorithm requires robust performance, less computing resources and easy design procedure with respect to the uncertain target maneuvering. To solve these problems, an adaptive fuzzy interacting multiple model (AFIMM) algorithm, which is based on the well-defined basis sub-models and well-adjusted mode transition probabilities (MTPs), is proposed. Simulation results show that the proposed algorithm effectively solves the problems in the real system application of the IMM-based position tracking algorithm.

Key Words : Maneuvering target, Position tracking, Adaptive fuzzy IMM, Basis sub-model, Mode transition probabilities

1. 서 론

최적 필터 이론에 기초한 칼만 필터(Kalman Filter)는 표적 추적에 널리 사용되어 왔다. 그러나 기동 표적 추적에 있어서 단일 필터가 사용되면 그 성능이 저하된다. 이러한 이유로 많은 종류의 칼만 필터 알고리즘들이 연구되어 왔다. 그 중에서도 IMM(Interacting Multiple Model) 알고리즘이 다양한 표적의 기동에 대해서 좋은 성능을 갖는 것으로 알려져 있다 [1-4].

IMM 알고리즘의 성능에 있어서, 표적의 기동이 부모델 (sub-model)의 출력과 유사하면 추적 오차는 작고, 그렇지 않으면, 그 오차는 상대적으로 크다. 이러한 이유로, IMM 알고리즘이 다양한 표적의 기동에 대해서 좋은 성능을 갖기 위해서는 많은 수의 부모델들을 필요로 한다. 그러나 많은 연산량을 필요로 하는 알고리즘을 사용하는 것은 실제 시스템 적용에 있어서 바람직하지 않다. 따라서 다양한 표적의 기동에 대해서 좋은 성능뿐만 아니라 적은 연산량을 갖는 IMM 알고리즘이 필요하다.

이 문제를 해결하기 위하여 IMM 알고리즘의 부모델 수를 최소화하고, 표적의 기동에 대한 최적의 부모델을 찾기 위해

서 유전 알고리즘(genetic algorithm : GA)을 사용하여 부모델의 파라미터를 조정하는 알고리즘이 제안되었다 [5]. 이 알고리즘은 좋은 성능뿐만 아니라 적은 수의 부모델을 가지기는 하지만 GA를 사용하여 부모델을 최적화하는데 있어 여전히 연산 부하를 가지고 있다.

그런데, IMM 알고리즘의 성능은 모델 천이 확률(mode transition probabilities)에도 의존한다. 모델 천이 확률이 시변값을 가지면 IMM 알고리즘의 성능은 시불변 모델 천이 확률을 갖는 기존의 IMM 알고리즘보다 우수하다. 이러한 의미에서 모델 천이 확률을 조정하는 알고리즘이 제안되었다 [6]. 이 알고리즘은 좋은 성능에도 불구하고 복잡한 수식으로 인하여 모델 천이 확률을 결정하는데 어려움이 있다. 이러한 문제들을 해결하기 위해 기저(basis) 부모델 및 시변 모델 천이 확률을 갖는 퍼지 IMM 알고리즘이 제안되었으나, 모델 천이 확률의 정확도 관점에서 성능 개선이 요구되었다 [7].

이러한 문제들을 재 해결하기 위하여 추적 대상의 기동 특성을 고려하여 결정된 최소한의 기저 부모델 수를 가지며 퍼지 입력으로서 모드 확률(mode probability)을 사용하여 모델 천이 확률을 조정하는 퍼지 IMM 알고리즘 [7, 8]에 기반하여 표적 기동에 따라 멤버쉽 함수의 폭을 자동적으로 조정하는 적응 퍼지 IMM 알고리즘을 제안하고자 한다. 추적 대상의 기동 특성을 고려하여 최소한의 기저 부모델을 정의하게 되면 제안된 알고리즘은 적은 연산량을 갖게 되고, 모드 확률이 퍼지 입력으로서 사용되면 제안된 알고리즘은 다

음의 장점을 갖는다. 즉, 이 알고리즘은 단순화(simplified) 퍼지 추론 방법 [9]을 쉽게 확장하여 적용할 수 있으며, 모드 확률 자체가 정규화된 값이므로 퍼지 입력을 정규화할 필요가 없으며, 퍼지 분할이나 퍼지 룰과 같은 설계 요소에 전문가의 지식을 쉽게 도입할 수 있다.

IMM 알고리즘은 2장에서 소개되며, AFIMM 알고리즘의 설계는 3장에서 설명된다. 그리고 시뮬레이션 결과는 4장에 기술된다. 마지막으로, 결론은 5장에 요약된다.

2. IMM 알고리즘의 소개

이 장에서는 칼만 필터에 기초한 IMM 알고리즘의 주요 요소가 소개된다. 자세한 내용은 참고문헌 [2]에 잘 설명되어 있다. Markov 사슬(chain)과 관련한 모델 천이 확률은 다음과 같이 정의된다.

$$\begin{aligned} p_{ij} &= P\{M_j(k)|M_i(k-1)\} \\ &= \begin{bmatrix} p_{11} & p_{12} & \cdots & p_{1r} \\ p_{21} & p_{22} & \cdots & p_{2r} \\ \vdots & \vdots & \ddots & \vdots \\ p_{r1} & p_{r2} & \cdots & p_{rr} \end{bmatrix} \end{aligned} \quad (1)$$

여기서, $i, j = 1, \dots, r$ 이고, r 은 부모델의 수이다.

다음으로, 합병(merging) 확률은 다음과 같이 정의된다.

$$\mu_{ij}(k-1|k) = \frac{1}{c_j} p_{ij} \mu_i(k-1) \quad (2)$$

여기서, c_j 는 j 번째 부모델의 정규화 상수이다.

$$c_j = \sum_{i=1}^r p_{ij} \mu_i(k-1) \quad (3)$$

그리고 혼합(mixed) 상태와 공분산은 다음과 같이 정의된다.

$$\hat{x}_0^j(k|k) = \sum_{i=1}^r \hat{x}^i(k|k) \mu_{ij}(k-1|k) \quad (4)$$

$$P_0^j(k|k) = \sum_{i=1}^r \mu_{ij}(k-1|k) \left[P^i(k|k) + [\hat{x}^i(k|k) - \hat{x}_0^j(k|k)] [\hat{x}^i(k|k) - \hat{x}_0^j(k|k)]^T \right] \quad (5)$$

여기서, $\hat{x}^i(k|k)$ 는 k 스캔에서의 상태 벡터이다.

또한 모드 확률은 다음과 같이 정의된다.

$$\mu_j(k) = \frac{1}{c} \Lambda_j(k) c_j \quad (6)$$

여기서, c 는 정규화 상수이다.

$$c = \sum_{j=1}^r \Lambda_j(k) c_j \quad (7)$$

여기서, $\Lambda_j(k)$ 는 likelihood 함수이다.

최종적인 결합(combined) 상태와 공분산은 다음과 같이 정의된다.

$$\hat{x}(k|k) = \sum_{j=1}^r \hat{x}^j(k|k) \mu_j(k) \quad (8)$$

$$P(k|k) = \sum_{j=1}^r \mu_j(k) \left[P^j(k|k) + [\hat{x}^j(k|k) - \hat{x}(k|k)] [\hat{x}^j(k|k) - \hat{x}(k|k)]^T \right] \quad (9)$$

위 방정식들로부터 IMM 알고리즘의 성능은 부모델들과 모델 천이 확률에 의존함을 알 수 있다.

표적 기동이 부모델의 출력과 유사하면 추적 오차는 작고, 그렇지 않으면 그 오차는 상대적으로 크다. 그리고 식 (1)의 모델 천이 확률이 조정되어 지면 IMM 알고리즘의 성능은 시불변 모델 천이 확률을 갖는 기존의 IMM 알고리즘보다 우수하다. 즉, 식 (1)의 임의의 열(column)의 값이 증가되면 해당 부모델이 식 (8)의 결합 상태를 생성하는데 지배적으로 반영되고, 식 (1)의 모든 열의 값이 동일하게 할당되면 모든 부모델이 식 (8)의 결합 상태를 생성하는데 동등하게 반영된다.

3. AFIMM 알고리즘의 설계

이 장에서는 추적 대상의 기동 특성을 고려하여 결정된 최소한의 부모델 수를 가지며 퍼지 입력으로서 모드 확률을 사용하여 모델 천이 확률이 표적 기동에 따라 적응적으로 조정되는 AFIMM 알고리즘이 제안된다.

퍼지 추론기(fuzzy decision maker)를 갖는 AFIMM 알고리즘의 한 주기는 그림 1에 보여 진다.

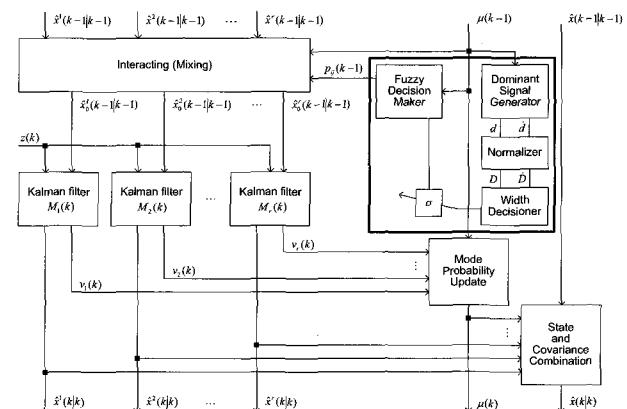


그림 1. AFIMM 알고리즘.

Fig. 1. AFIMM algorithm.

본 논문에서 AFIMM 알고리즘의 상세 설계 절차는 다음의 세 가지 단계로 나누어진다.

AFIMM 알고리즘 설계의 첫 번째 단계에서는, 표적의 기동 특성을 고려하여 AFIMM 알고리즘의 기저 부모델들이 정의된다. 일반적인 표적의 기동 특성은 다음과 같이 표현될 수 있다.

$$\text{Maneuvering Property} = f(v, a, \omega, T, \sigma_w) \quad (10)$$

여기서, v 는 표적 속력, a 는 표적 가속도, ω 는 표적 각속도, T 는 샘플링 주기, 그리고, σ_w 은 측정 잡음의 표준 편차이다.

표적 속력, 표적 가속도, 표적 각속도, 샘플링 주기, 측정 잡음의 표준 편차와 같은 추적 대상의 기동 특성이 부모델의 정의에 고려되어 지면, 최소한의 부모델 수를 결정할 수 있다. 즉, 대표적인 표적 기동 특성은 알려져 있으므로 표적의

기동이 백색 가우시안 프로세스 잡음을 갖는 경우를 가정하면, 등속도(constant velocity : CV) 모델, Singer(SG) 모델 [10], 등가속도(constant acceleration : CA) 모델, 회전(coordinated turn) 모델과 같은 동역학적 모델 가운데에서 표적의 속력을 고려하여 부모델을 선택할 수 있다. 그런데, 샘플링 주기가 짧고 측정 잡음이 크면 불필요한 부모델이 존재하므로 부모델의 수는 감소될 수 있다. 여기서 SG 및 CA 모델은 불필요한 모델이 될 수 있는데, 왜냐하면 CV 및 CT 모델의 가중합(weighted-sum)에 의해서 생성될 수 있는 모델이기 때문이다. 그리고 CT 모델의 경우에 표적의 회전 방향은 알 수 없지만 최대 회전율은 일반적인 추적 시스템에서 알고 있는 값으로 최대값으로서의 ω 가 결정 가능하다. 기동 특성의 분석과 관련하여 앞의 내용을 요약하면, 본 논문에서 제안된 AFIMM의 기저 부모델은 CV 및 CT 모델이 될 수 있다. 즉, CV 1개와 시계/반시계 방향 CT 각 1개의 총 3개의 기저 부모델을 정의할 수 있다.

위의 과정으로부터 추적 대상의 기동 특성을 고려하여 기저 부모델을 정의하였다. 기저 부모델은 표적 추적에 필요한 최소한의 모델 수를 가지므로, 이를 통하여 제안된 알고리즘은 적은 연산량을 갖는다.

AFIMM 알고리즘 설계의 두 번째 단계에서는 퍼지 입력으로서 모드 확률을 사용하여 모델 천이 확률을 조정하는 퍼지 추론기가 설계된다.

식 (1)의 모델 천이 확률을 조정하기 위해서, 각각의 부모델들을 평가하기 위한 성능 지표가 요구된다. 식 (6)에서, 모드 확률은 각각의 부모델을 평가할 수 있는 가능성(likelihood) 함수를 포함하고 있다. 따라서 모드 확률이 퍼지 입력으로서 사용된다.

퍼지 추론기를 위한 퍼지화(fuzzification)는 종형(bell-shaped)의 멤버쉽 함수(membership function) 5개를 사용한다. 퍼지화와 관련된 퍼지 분배(fuzzy partition)은 그림 2에 보여 진다.

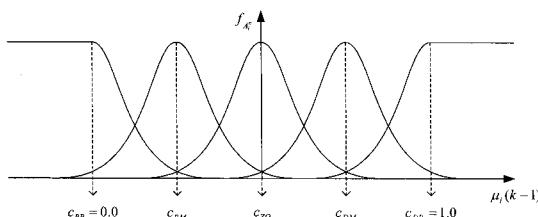


그림 2. 퍼지 분배.
Fig. 2. Fuzzy Partition.

이 퍼지 분할은 식 (6)의 모드 확률이 0에서 1의 값을 가지고 있다는 사실 뿐만 아니라 우성(dominant)과 열성(recessive)의 부모델이 존재한다는 개념을 사용하고 있다. 이는 퍼지 입력으로서 모드 확률을 사용하는 것과 밀접한 관련이 있다.

전문가의 지식으로부터, RB, ZO 및 DB 멤버쉽 함수의 중심들은 다음과 같이 쉽게 정해진다.

$$\begin{cases} c_{RB} = 0.0 \\ c_{ZO} = 1/r \\ c_{DB} = 1.0 \end{cases} \quad (11)$$

그리고 RM 및 DM 멤버쉽 함수의 중심들은 부모델간의

유사도를 고려함으로써 적절히 정해진다. 즉, 부모델들 간에 유사도가 높으면, c_{RM} 및 c_{DM} 은 c_{ZO} 에 가까워지고, 그렇지 않으면 그들은 c_{ZO} 에서 멀어진다.

퍼지 추론기를 위한 퍼지 추론 방법은 결론부가 상수 형태를 갖는 단순화 추론 방법을 사용한다. 앞서 언급한 모델 천이 확률은 행렬의 형태를 가지므로, 상수를 행렬로 확장할 필요가 있다.

퍼지 추론 방법과 관련한 퍼지 룰은 다음의 형태로 표현된다.

$$\begin{aligned} R^n : & \text{ if } \mu_1 \text{ is } A_1 \text{ and } \mu_2 \text{ is } A_2 \text{ and } \dots \text{ and } \mu_r \text{ is } A_r \\ & \text{ then } p_{ij} = p_{ij}^n \end{aligned} \quad (12)$$

여기서, $R^n (n=0, 1, \dots, 3)$ 은 n 번째 퍼지 룰을 나타내며, μ_i 는 식 (2)의 모드 확률이고, A_i 는 i 번째 퍼지 멤버쉽 함수를 나타낸다. 그리고, p_{ij}^n 는 n 번째 퍼지 룰의 모델 천이 행렬을 나타낸다.

일반적으로, 우성의 부모델의 수는 부모델의 수에 비례한다. 하지만 식 (10)의 분석에 의해 정의된 부모델은 유사도가 매우 낮으므로 본 퍼지 룰에는 단 하나의 우성의 부모델이 고려된다. 따라서, 이 룰은 각각의 기저 부모델이 우성인 경우와 모든 부모델의 우성이 정도가 동일한 경우가 존재한다는 가정을 사용한다. 이 또한 퍼지 입력으로서 모드 확률을 사용하는 것과 밀접한 관련이 있다.

전문가의 지식으로부터, 퍼지 결론부를 구성하는 행렬 p_{ij}^n 은 다음과 같이 표현된다.

$$p_{ij}^n = \begin{bmatrix} p_1 & p_2 & \dots & p_j \\ p_1 & p_2 & \dots & p_j \\ \vdots & \vdots & \ddots & \vdots \\ p_1 & p_2 & \dots & p_j \end{bmatrix} \quad (13)$$

여기서,

$$p_j = \begin{cases} 1/r, & n=0 \\ p_{\max}, & n \neq 0 \text{ and } j=n \\ (1-p_{\max})/(r-1), & n \neq 0 \text{ and } j \neq n \end{cases} \quad (14)$$

앞의 내용에 근거하여 제안된 퍼지 룰은 다음과 같이 표현된다 [7, 8].

- $$\begin{aligned} R^0 : & \text{ if } \mu_1 \text{ is } ZO \text{ and } \mu_2 \text{ is } ZO \text{ and } \mu_3 \text{ is } ZO \\ & \text{ then } p_{ij} = p_{ij}^0 \\ R^1 : & \text{ if } \mu_1 \text{ is biggerthan } DM \text{ and } \mu_2 \text{ is smallerthan } RM \text{ and } \mu_3 \text{ is smallerthan } RM \\ & \text{ then } p_{ij} = p_{ij}^1 \\ R^2 : & \text{ if } \mu_1 \text{ is biggerthan } DM \text{ and } \mu_2 \text{ is smallerthan } RM \text{ and } \mu_3 \text{ is smallerthan } RM \\ & \text{ then } p_{ij} = p_{ij}^2 \\ R^3 : & \text{ if } \mu_1 \text{ is biggerthan } DM \text{ and } \mu_2 \text{ is smallerthan } RM \text{ and } \mu_3 \text{ is smallerthan } RM \\ & \text{ then } p_{ij} = p_{ij}^3 \end{aligned} \quad (15)$$

그런데, 퍼지 룰을 구성하는 멤버쉽 함수의 폭은 퍼지 분배 상태를 고찰하여 비교적 쉽게 그 최대 범위를 정할 수 있고 퍼지 추론기의 출력이 이 값에 민감하므로 매우 실용적인 파라미터이다. 즉, 이 값이 표적의 기동에 대해서 잘 조정되어 지면 기저 부모델의 혼합률이 조정될 수 있으므로 퍼지 추론기의 성능이 개선되어 질 수 있다. 더불어 본 논문에서는 설계의 용이성을 위하여 모든 멤버쉽 함수의 폭을 동일하게 정하였다.

AFIMM 알고리즘 설계의 세 번째 단계에서는 퍼지 입력

으로서 우성 신호를 사용하여 퍼지 추론기의 멤버쉽함수 폭을 조정하는 적용 퍼지 추론기가 추가적으로 설계된다. 우성 부모델의 존재를 알기위한 지표로서의 우성 신호는 다음과 같다.

$$d = \max(\mu_i(k-1)) - c_{ZO} \quad (16)$$

만약에, 우성 부모델이 존재하면, 우성 신호의 값은 커지고, 이 값은 쉽게 $1 - c_{ZO}$ 에 의해서 정규화된다.

앞의 내용에 근거하여 제안된 퍼지 적용률은 다음과 같이 표현된다.

$$R^m: \text{if } Dis B_1^m \text{ and } Dis B_2^m \text{ then } \sigma = \sigma^m \quad (17)$$

여기서, $R^m (m=1, 2, \dots, 5^2)$ 은 m 번째 퍼지률이고, D 및 \dot{D} 는 d 및 \dot{d} 의 정규화된 값들이다. σ 는 그림 2에 보여진 퍼지 멤버쉽 함수의 폭이다. 퍼지 추론기의 구성을 용이하게 한다. B_1^m 은 very small(VS), small(S), medium(M), big(B) 및 very big(VB)으로 표현되는 언어항이고, B_2^m 은 negative big(NB), negative medium(NM), zero(ZO), positive medium(PM) 및 positive big(PB)으로 표현되는 언어항이다.

표 1은 앞의 내용에 근거하여 제안된 적용 퍼지률이다.

표 1. 적용 퍼지률.

Table 1. Adpative fuzzy rule.

	NB	NM	ZO	PM	PB
VS	0.001	0.011	0.021	0.011	0.001
S	0.301	0.311	0.321	0.311	0.301
M	0.901	0.911	0.921	0.911	0.901
B	0.301	0.311	0.321	0.311	0.301
VB	0.001	0.011	0.021	0.011	0.001

이 표는 비교적 단순한 형태의 다음의 두 가지 룰을 포함하고 있다. 즉, D 가 매우 작거나 매우 크면, 식 (15)에서 p_{ij}^0 와 다른 값들의 혼합률을 감소시키기 위해서 퍼지 멤버쉽 함수의 폭을 감소시키고, 그렇지 않으면, 그 폭은 증가되어 진다. 또한, \dot{D} 가 NB이거나 PB이면, 혼합률을 감소하기 위해서 그 폭을 감소시키고, 그렇지 않으면, 그 폭은 증가되어 진다.

퍼지 추론기를 위한 비퍼지화(defuzzification)은 다음의 형태로 표현된다.

$$p_{ij}(k) = \frac{\sum_{n=0}^r w_n p_{ij}^n}{\sum_{n=0}^r w_n} \quad (18)$$

여기서,

$$w_n = \prod_{i=1}^r f_{A_i^n}(\mu_i(k-1)) \quad (19)$$

적용 퍼지 추론기를 위한 비퍼지화(defuzzification)은 다음의 형태로 표현된다.

$$\sigma(k) = \frac{\sum_{m=1}^{5^2} w_m \sigma^m}{\sum_{m=1}^{5^2} w_m} \quad (20)$$

여기서,

$$w_m = f_{B_1^m}(D) \cdot f_{B_2^m}(\dot{D}) \quad (21)$$

결론적으로, 이 퍼지 추론기는 적용적으로 식 (1)의 시불변 p_{ij} 를 식 (18)의 시변 $p_{ij}(k)$ 로 교체한다.

위의 과정으로부터 모드 확률이 퍼지 입력으로서 사용되는 퍼지 추론기를 설계하였다. 이를 통하여 제안된 알고리즘은 다음의 장점을 갖는다. 즉, 이 알고리즘은 단순화 퍼지 추론 방법을 쉽게 확장하여 적용할 수 있으며, 모드 확률 자체가 정규화된 값이므로 퍼지 입력을 정규화할 필요가 없으며, 퍼지 분할이나 퍼지 룰과 같은 설계 요소에 전문가의 지식을 쉽게 도입할 수 있다. 또한, 개선된 위치 추적 성능을 갖는다.

4. 시뮬레이션 결과

AFIMM 알고리즘의 성능 검증은 수평면에서 등속도 및 회전 운동을 하는 공중 비행 표적의 추적 문제에 대해서 이루어졌다.

등속도 및 회전 운동과 관련된 프로세스 방정식은 다음과 같이 정의된다.

$$\mathbf{x}(k+1) = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \mathbf{x}(k) + \begin{bmatrix} T^2/2 \\ T \\ T^2/2 \\ T \end{bmatrix} v(k) \quad (22)$$

$$\mathbf{x}(k+1) = \begin{bmatrix} 1 & \sin\theta/T/\omega & 0 & -(1-\cos\theta)/\omega \\ 0 & \cos\theta & 0 & -\sin\theta \\ 0 & (1-\cos\theta)/\omega & 1 & \sin\theta/T/\omega \\ 0 & \sin\theta & 0 & \cos\theta \end{bmatrix} \mathbf{x}(k) + \begin{bmatrix} T^2/2 \\ T \\ T^2/2 \\ T \end{bmatrix} v(k) \quad (23)$$

여기서, T 는 샘플링 주기이다.

상태 벡터는 다음과 같이 정의된다.

$$\mathbf{x}(k) = [\xi \ \dot{\xi} \ \eta \ \dot{\eta}]^T \quad (24)$$

여기서, ξ 및 $\dot{\xi}$ 는 직교좌표계상에서 x 축에 대한 표적의 위치와 속력에 해당하고, η 및 $\dot{\eta}$ 는 y 축에 대한 표적의 위치와 속력에 해당한다. 측정 방정식은 다음과 같이 정의된다.

$$\mathbf{z}(k) = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \mathbf{x}(k) + w(k) \quad (25)$$

기동 표적의 시뮬레이션 시나리오는 다음과 같이 정의된다.

먼저, 0~70 초 동안에는 300 m/s 의 속력을 갖는 비기동(non-maneuvering) 비행이고, 70~115.5 초 동안에는 $3.74^\circ/\text{s}$ (2g 가속)의 회전률을 갖는 180° 회전 비행이다. 115.5~

185.5 초 동안에는 300 m/s 의 속력을 갖는 비기동 비행이고, 185.5~231 초 동안에는 $-3.74^\circ/\text{s}$ 의 회전률을 갖는 -180° 회전 비행이다. 또한, 231~301 초 동안에는 300 m/s 의 속력을 갖는 비기동 비행이고, 301~392 초 동안에는 $1.87^\circ/\text{s}$ (g 가속)의 회전률을 갖는 180° 회전 비행이다. 392~462 초 동안에는 300 m/s 의 속력을 갖는 비기동 비행이고, 462~553 초 동안에는 $-1.87^\circ/\text{s}$ 의 회전률을 갖는 -180° 회전 비행이다. 마지막으로, 553~700 스캔 동안에는 300 m/s 의 속력을 갖는 비기동 비행이다.

표적의 초기 상태는 다음과 같이 결정되었다.

$$\mathbf{x}(0) = [30000 \ -172 \ 30000 \ -246]^T$$

프로세스 잡음의 표준편차는 영이다.

실제 궤적은 그림 3에 보여진다.

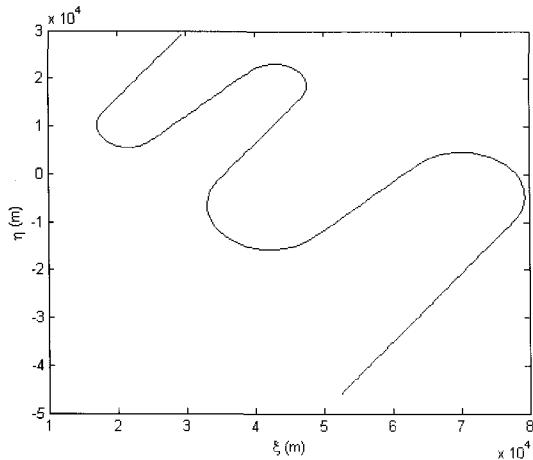


그림 3. 실제 궤적.

Fig. 3. True trajectory.

센서 시스템의 샘플링 주기는 $T=3.5$ 이다.

센서 시스템의 측정 잡음은 $\sigma_w = 30.0$ 이다.

추적 필터에 사용된 부모델은 다음과 같다.

$$\mathbf{M} = [\omega_1 = 0, \omega_2 = 2g, \omega_3 = -2g]^T \quad (26)$$

추적 필터에 사용된 프로세스 잡음의 공분산은 다음과 같다.

$$\mathbf{Q} = \begin{bmatrix} T^4/4 & T^3/2 & 0 & 0 \\ T^3/2 & T^2/2 & 0 & 0 \\ 0 & 0 & T^4/4 & T^3/2 \\ 0 & 0 & T^3/2 & T^2/2 \end{bmatrix} \sigma_v^2 \quad (27)$$

여기서, $\sigma_v = 0.004$ 이다.

추적 필터에 사용된 측정 잡음은 σ_w 와 동일하다.

퍼지 분할의 파라미터는 $c_{DM} = 0.66$ 와 같이 결정되었다. 퍼지 룰의 파라미터는 $p_{max} = 0.98$ 이다.

기존의 알고리즘과 AFIMM 알고리즘의 성능을 비교하기 위해서 IMM1과 IMM2를 위한 p_{ij1} 및 p_{ij2} 가 고려되었다.

p_{ij1} 은 전문가의 지식을 사용하지 않고 균일하게 초기화된 경우이고, p_{ij2} 는 경험적인 전문가의 지식을 사용하는 경우이다.

$p_{ij}(0)$ 은 AFIMM 알고리즘의 초기값이다. 이들은 다음과 같이 결정되었다.

$$p_{ij1} = p_{ij}(0) = \begin{bmatrix} 0.33 & 0.33 & 0.33 \\ 0.33 & 0.33 & 0.33 \\ 0.33 & 0.33 & 0.33 \end{bmatrix}$$

$$p_{ij2} = \begin{bmatrix} 0.95 & 0.05 & 0.05 \\ 0.025 & 0.70 & 0.25 \\ 0.025 & 0.25 & 0.70 \end{bmatrix}$$

AFIMM의 성능 검증은 100번의 Monte Carlo 시뮬레이션에 의해서 이루어졌다. 그 결과는 그림 4~9에 보여 진다.

그림 4 및 5는 ξ 축에 대한 표적의 위치 및 속력의 RMSE를 보여준다. 그리고, 그림 6 및 7은 η 축에 대한 표적의 위치 및 속력의 RMSE를 보여준다. 지배적으로 우성인 부모델이 존재하지 않는 301~392 및 462~553초의 경우에는 AFIMM 알고리즘은 IMM1보다 우수하고, IMM1은 IMM2보다 우수하다. 그리고 지배적으로 우성인 부모델이 존재하는 경우에는 AFIMM 알고리즘은 IMM2보다 성능이 떨어지긴 하나, IMM1보다는 우수하다. 이들은 전체 표적 기동에 대해서 AFIMM이 가장 장인함을 의미하며, 실제 적용의 경우에서처럼 표적의 기동이 기저 부모델과 일치하지 않는 경우가 많을 수록 그 효과는 커짐을 보여준다.

표 2는 전체 표적 기동에 대한 RMSD의 평균값으로서의 IMM1, IMM2 및 AFIMM 알고리즘의 성능 비교를 보여준다. 이들 값들은 AFIMM이 전체 표적 기동에 대해서 가장 장인함을 정량적으로 검증하여 준다.

표 2. 성능 비교.
Table 2. Comparison of performance.

	$ \dot{\xi}_e _{avg}$	$ \dot{\eta}_e _{avg}$	$ \dot{\eta}_e _{avg}$	$ \dot{\eta}_e _{avg}$	CPU time [s]
IMM1	25.041	13.885	23.906	12.658	0.0033
IMM2	23.765	13.304	22.740	13.038	0.0033
AFIMM	23.714	9.137	22.467	8.559	0.0048

이들 비교는 연산량과 직접 관련이 있는 부모델의 개수의 최소화와 최적의 성능을 보장하기 위한 모델 천이 확률의 최적화 관점에서 AFIMM의 우수성을 보이고 있다. 즉, 표적의 기동이 다양해질수록 기존의 IMM 알고리즘은 좋은 성능을 얻기 위해서는 많은 부모델을 필요로 하므로 많은 연산량을 요구하는 반면에 AFIMM은 추적 대상의 분석을 통하여 최소한의 기저 부모델을 사용하고, 이로 인하여 생길 수 있는 단점을 보완하기 위해서 설계가 용이한 퍼지 추론기에 대해서 최적화된 모델 천이 확률을 사용하므로 연산량이 크게 증가하지 않는다.

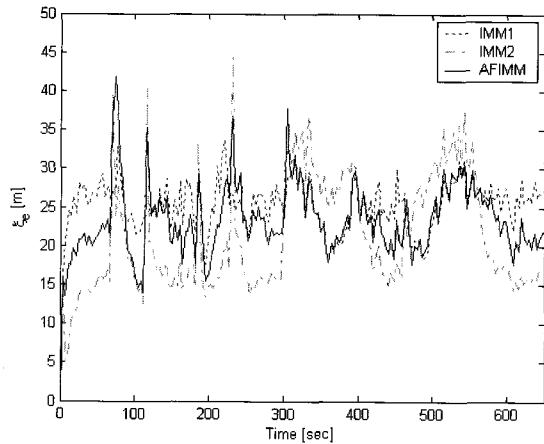


그림 4. 표적 위치 (ξ -축).
Fig. 4. Target position (ξ -axis).

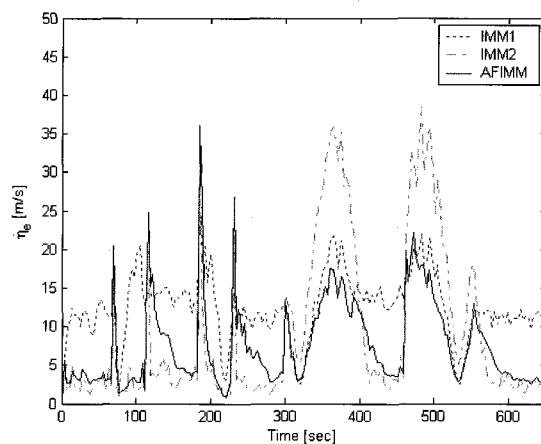


그림 7. 표적 속도 (η -축).
Fig. 7. Target velocity (η -axis).

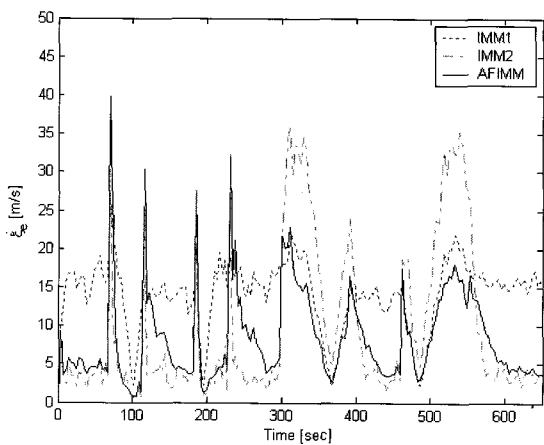


그림 5. 표적 속도 (ξ -축).
Fig. 5. Target velocity (ξ -axis).

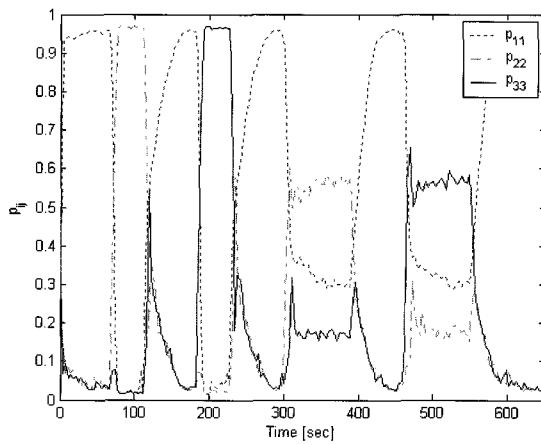


그림 8. 모델 천이 확률.
Fig. 8. Mode transition probability.

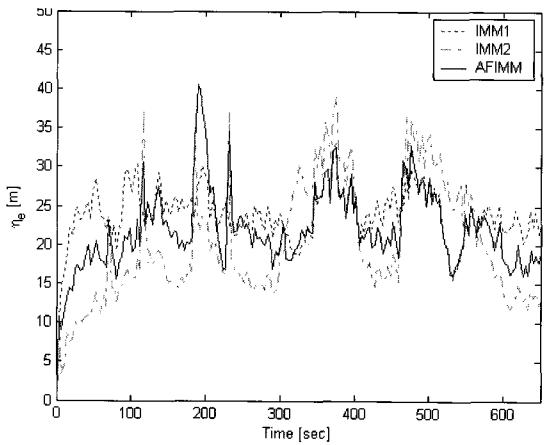


그림 6. 표적 위치 (η -축).
Fig. 6. Target position (η -axis).

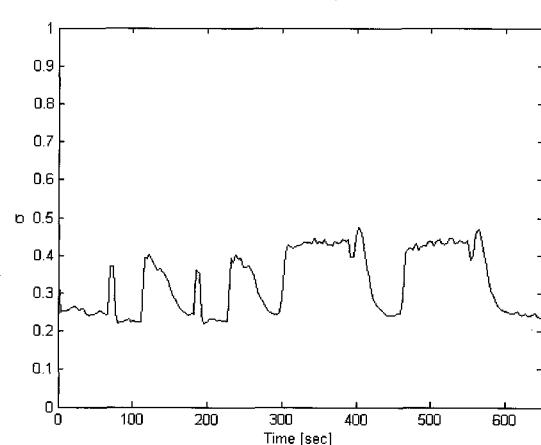


그림 9. 멤버쉽 함수 폭.
Fig. 9. Membership function width.

앞의 그림 8은 모델 천이 확률의 RMS 값을 보여 주는데, 참고문헌 [7]에 비해 퍼지 추론기가 기저 부모델을 매우 잘 혼합하여 표적 기동의 변화에 대해 효과적으로 대처하고 있음을 보여 준다. 그리고, 앞의 그림 9는 퍼지 멤버쉽 함수의 폭을 보여 주는데, 적응 퍼지 추론기가 정해진 적응률 대로 그 폭을 효과적으로 조정하고 있음을 보여준다.

앞의 결과로부터 AFIMM은 퍼지 입력으로서 모델 천이 확률을 적응적으로 조정하므로 기동 표적 추적에 매우 효과적임을 알 수 있다.

본 논문에서는 추적 대상의 기동 특성을 고려하여 결정된 최소한의 부모델 수를 가지며 퍼지 입력으로서 모드 확률을 사용하여 모델 천이 확률을 조정하는 AFIMM이 설계되었다.

설계의 첫 번째 과정에서는 추적 대상의 기동 특성을 고려하여 AFIMM의 기저 부모델을 정의하였다. 이를 통하여 제안된 알고리즘이 적은 연산량을 갖도록 하였다.

설계의 두 번째 과정에서는 모드 확률이 퍼지 입력으로서 사용되는 퍼지 추론기를 설계하였다. 이를 통하여 제안된 알고리즘은 다음의 장점을 갖도록 하였다. 즉, 이 알고리즘은 단순화 퍼지 추론 방법을 쉽게 확장하여 적용할 수 있으며, 모드 확률 자체가 정규화된 값이므로 퍼지 입력을 정규화할 필요가 없으며, 퍼지 분할이나 퍼지 룰과 같은 설계 요소에 전문가의 지식을 쉽게 도입할 수 있다.

설계의 세 번째 과정에서는 퍼지 추론기의 멤버쉽 함수의 폭을 결정하기 위한 적응 퍼지 추론기를 설계하였다. 이를 통하여 제안된 알고리즘이 매우 효과적인 적응성을 갖게 하였다.

AFIMM의 성능을 검증하기 위해서 대공 표적 추적이 수행되었다. Monte Carlo 시뮬레이션을 통한 그 결과들은 AFIMM이 추적 대상의 기동 특성을 고려하여 결정된 최소한의 부모델 수를 가지며 퍼지 입력으로서 모드 확률을 사용하여 모델 천이 확률을 조정하므로 기동 표적 추적에 매우 효과적임을 보였다.

참 고 문 헌

- [1] H. A. P. Blom, and Y. Bar-Shalom, "The interacting multiple model algorithm for systems with a jump-linear smoothing application," *IEEE Transactions on Automatic Control*, Vol. AC-33, No. 8, pp. 780-783, 1988.
- [2] Y. Bar-Shalom, and Xiao-Rong Li, "Estimation and Tracking Principles, Techniques and Software," Artech House, Inc, 1993.
- [3] X Rong Li, "Design of an Interacting Multiple Model Algorithm for Air Traffic Control Tracking," *IEEE Transactions on Control Systems Technology*, Vol. 1, No. 3, pp. 186-194, 1993.
- [4] Y. Bar-Shalom, K. C. Chang, and H. A. P. Blom, "Tracking a manoeuvring target using input estimation versus the interacting multiple model algorithm," *IEEE Transactions on Aerospace and Electronic Systems*, Vol. AES-25, pp. 296-300, 1989.
- [5] Bum-Jik Lee, Young-Hoon Joo, and Jin-Bae Park, "Estimating optimal tracking filter performance

for manned maneuvering targets," *International Journal of Control, Automation, and Systems*, Vol. 1, No. 1, pp. 93-100, 2003.

- [6] L. Campo, P. Mookerjee, and Y. Bar-Shalom, "State Estimation for Systems with Sojourn-Time-Dependent Markov Model Switching," *IEEE Transaction on Automatic Control*, Vol. 36, No. 2, pp. 238-243, 1991.
- [7] H. S. Kim, and S. Y. Chun, "Design of fuzzy IMM algorithm based on basis sub-models and time-varying mode transition probabilities," *International Journal of Control, Automation, and Systems*, Vol. 4, No. 5, pp. 559-566, 2006.
- [8] 김현식, 김진석, 황수복, "기동 표적 추적을 위한 퍼지 IMM 알고리즘에 관한 연구," *한국군사과학기술학회 논문지*, 제7권, 제4호, pp. 5-12, 2004.
- [9] T. Takagi, and M. Sugeno, "Fuzzy identification of system and its applications to modeling and control," *IEEE Transactions on Man and Cybernetics*, Vol. SMC-15, pp. 116-132, 1985.
- [10] R. A. Singer, "Estimating Optimal Tracking Filter Performance for Manned Manoeuvring Targets," *IEEE Transactions on Aerospace and Electronic Systems*, Vol. AES-6, No. 4, pp. 473-483, 1970.]

저 자 소 개



김현식(Hyun-Sik Kim)

1994년 : 부산대학교 전기공학과 졸업.

1996년 : 부산대학교 전기공학과 졸업
(공학석사)

2001년 : 부산대학교 전기공학과 졸업
(공학박사)

1998년~2007년 : 국방과학연구소 선임
연구원

2007년~현재 : 동명대학교 로봇시스템공학과 전임강사

관심분야 : 인공지능/퍼지이론/진화연산, 로보틱스, 수중운동
체 제어, 수중표적 탐지/추적/식별

Phone : 051-620-3747

Fax : 051-610-8845

E-mail : hyunskim@tu.ac.kr